

## 激光与光电子学进展

## 基于深度卷积生成对抗网络的鬼成像质量优化

侯茂新<sup>1\*</sup>, 刘昭涛<sup>2</sup><sup>1</sup>中兵智能创新研究院有限公司群体协同与自主实验室, 北京 100072;<sup>2</sup>中国北方车辆研究所, 北京 100072

**摘要** 针对传统鬼成像在识别手写数字时所存在的重构图像质量差的问题, 结合生成对抗网络生成数据快的优势, 提出一种新的鬼成像质量优化方法, 以提升低采样率下鬼像的重构质量。通过桶探测器收集由系列散斑照射到待测手写数字图像上的光强, 获得总光强值, 并将其输入适用于鬼成像原理的深度卷积生成对抗网络, 进行训练, 分别与传统鬼成像方法和 u-net 网络进行对比分析, 验证了所提方法的有效性和合理性。实验结果表明, 所提方法得到的重构图像质量明显优于对比方法的图像质量, 且在 0.0625、0.25 采样率下重构图像的峰值信噪比和结构相似度较 u-net 网络分别提升了 18.9%/51.9%、38.29%/42.35%。

**关键词** 鬼成像; 生成对抗网络; 低采样率; 峰值信噪比; 结构相似度

中图分类号 O431.2

文献标志码 A

DOI: 10.3788/LOP232421

## Ghost Imaging Quality Optimization Based on Deep Convolutional Generative Adversarial Networks

Hou Maoxin<sup>1\*</sup>, Liu Zhaotao<sup>2</sup>

<sup>1</sup>Collective Intelligence & Collaboration Laboratory, Zhongbing Intelligent Innovation Research Institute Limited Liability Company, Beijing 100072, China;

<sup>2</sup>China North Vehicle Research Institute, Beijing 100072, China

**Abstract** To address the problem of poor reconstructed image quality of traditional ghost imaging in handwritten digit recognition, this paper proposes a quality optimization method for ghost imaging based on the advantageous fast data generation in generative adversarial networks. The proposed method can improve the reconstruction quality of ghost images at a low sampling rate. Furthermore, the method concretely comprised the following steps: initially, a barrel detector collected the light intensity of the handwritten digital image irradiated by a series of scattering spots to obtain the total light intensity value; subsequently, a deep convolutional generative adversarial network applicable to the principle of ghost imaging was built, and the light intensity value was used as an input to train the model; finally, comparative analyses were performed with the traditional ghost imaging method and u-net network to verify the effectiveness and validity of the proposed method. The experimental results show that the reconstructed image obtained using the proposed method is considerably superior to the comparison methods. Additionally, at sampling rates of 0.0625 and 0.25, the peak signal-to-noise ratio and structural similarity of reconstructed image are 18.9%/51.9% and 38.29%/42.35% higher than those obtained using the u-net network, respectively.

**Key words** ghost imaging; generative adversarial network; low sampling rate; peak signal-to-noise ratio; structural similarity

## 1 引言

手写数字识别作为计算机视觉领域中一种重要的判别方法, 可在大幅减少人力的情况下提升识别效率。实际上, 由于个人书写风格迥异、书写习惯不同, 手写

数字存在较大的差异, 而不像印刷体有着统一的判别标准, 因此在手写数字识别中会出现识别效率低, 甚至无法识别的问题。而鬼成像作为一种反直觉间接成像方式, 无须事先获取物体的细节信息, 可在不直视目标物体的情况下实现对目标物体的快速成像<sup>[1-5]</sup>。目前

收稿日期: 2023-11-02; 修回日期: 2023-12-11; 录用日期: 2023-12-26; 网络首发日期: 2024-01-10

基金项目: “\*\*\*工程”预先研究项目(20220110)

通信作者: \*wang17835132895@163.com

鬼成像技术在实际生活中的应用既是研究的热点同时也是研究的难点<sup>[6-9]</sup>,由于手写数字的通用性,其可广泛应用于财务报表、金融统计、邮件分拣等领域。将鬼成像机理与手写数字识别技术相结合,在实现对手写数字识别的同时可有效避免图像特征细节信息缺失导致识别效率较低的问题。然后,如何以较小的采样率重构高质量的目标图像也是目前亟待解决的问题。

近年来,在采样率较低的情况下,即在测量次数较少时能进一步提高重构图像的视觉质量,基于深度学习的技术也广泛应用于鬼成像领域<sup>[10]</sup>。基于训练方法的鬼成像按照神经网络的输入,可大致分为两大类。一类输入为经传统鬼成像关联算法后的初始鬼像,该类方法通过网络训练的方式提高鬼像的信噪比,并未将深度学习与鬼成像算法结合起来。例如:冯维等<sup>[11]</sup>提出一种基于卷积神经网络的计算鬼成像方法,该方法将关联计算重建后的鬼像和相对应的目标图像作为卷积神经网络的输入,模型通过学习可在低采样情况下预测出相应的目标图像,但实际上只是对鬼成像的结果图像进行后续优化处理,并未考虑一维光强序列与二维重建图像之间的映射关系;Wei等<sup>[12]</sup>提出一种基于自动编码网络的鬼成像方法,该方法无需标记图像可在低采样率下获得较好的重构结果,但自编码网络在训练过程中只能将均方误差作为损失函数(只能粗略衡量误差),导致重建的鬼像不能很好地保留原图像的清晰度。另一类输入为一维桶探测器的值,该方法通过网络训练的方法找到了一维桶探测器的值与二维目标图像之间完整的映射关系。例如:司徒国海课题组<sup>[13]</sup>利用模拟数据训练端到端的神经网络,该方法可由一维光强序列直接重建二维图像;Yang等<sup>[14]</sup>针

对水下环境的复杂性会大幅度降低鬼像质量的问题,提出一种基于生成对抗网络的水下鬼成像方法,该方法促进了基于鬼成像的水下目标光学成像技术的进一步发展。基于深度学习思想提出的上述方法虽较高地提升了鬼像的信噪比,但仍存在所搭建的网络模型结构复杂从而导致训练时间长、模型泛化能力差、在低采样率条件下重构效果不理想的问题。而深度卷积生成对抗网络<sup>[15]</sup>在传统生成对抗网络的基础上,不仅利用卷积神经网络强大的特征提取能力,同时还可通过监督信息的引入和全卷积层来提升模型的泛化能力和稳定性<sup>[16]</sup>。如文献<sup>[17]</sup>通过将卷积生成对抗网络和注意力机制相结合,将重构的灰度鬼像转换为了彩色图像,较好保留了目标的颜色特征。

鉴于此,本文结合生成对抗网络数据生成速度快和卷积网络特征提取能力强的优势,提出一种基于监督学习的深度卷积生成对抗网络鬼成像方法(SDCGAN-GI),目的是提升重构的灰度鬼像质量,为后续的目标彩色化提供高质量输入数据。该方法以一维桶探测器的值及对应的目标图像作为网络的输入,并选用 Leaky ReLU 作为生成器和判别器的激活函数,其可有效改善梯度稀疏性从而提高重建鬼像的质量。将结合理论分析与实验验证,通过多组低采样率下重建鬼像结果与传统鬼成像结果的对比分析来说明所提方法的合理性和有效性。

## 2 算法原理及网络体系结构设计

### 2.1 算法原理

鬼成像的重构原理如图 1 所示,为了减少散斑冗余,确保重构鬼像质量,选用 Hadamard 散斑<sup>[18-19]</sup>,基

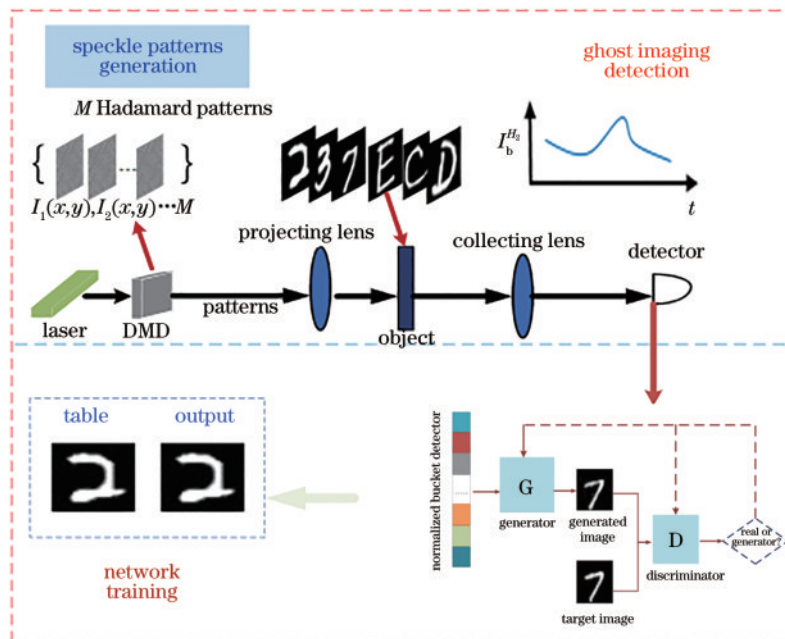


图 1 基于 Hadamard 散斑的计算鬼成像原理

Fig. 1 Schematic of computational ghost imaging based on Hadamard speckle

本实现过程如下。

1) 将激光器产生的光束照射到数字显微阵列 (DMD) 上, 将光束调制成 Hadamard 瞬时散斑光场, 记为  $I_m(x, y)$ 。

2) 将 Hadamard 瞬时散斑光场照射待测物体, 利用单像素探测器对待测物体反射的总光强值进行探测, 并实时记录  $t$  时刻下探测器数值  $I_b(t)$ , 即

$$I_b(t) = \int I_m(x, y) f(x, y) dx dy, \quad (1)$$

式中:  $f(x, y)$  为待测物体在  $(x, y)$  位置处的反射率。

3) 通过关联运算重构待测物体鬼像, 即

$$O(x, y) = \frac{1}{M} \sum_{m=1}^M [I_b(t) - \langle I_b(t) \rangle] I_m(x, y), \quad (2)$$

式中:  $O(x, y)$  为重构后待测物体鬼像;  $M$  为总采样次数;  $\langle \cdot \rangle$  表示统计平均。

### 2.2 基于深度卷积生成对抗网络的算法设计

深度卷积生成对抗网络主要由生成器和判别器<sup>[20-22]</sup>组成, 所采用的 SDCGAN-GI 架构具体如图 2 所示。由图 2 可知: 该方法生成器的输入为桶探测器的值转换后的一维向量 (记为  $B$ ) 和目标图像 (记为  $T$ ), 然后它生成符合目标图像作为标签条件的图像  $G(B|T)$ , 目的是让判别器尽可能以为生成的图像是真实样本; 对于判别器, 将生成器生成的图像 (记为  $O$ ) 和目标图像 (记为  $T$ ) 为其输入, 最后输出此图像在该条件下的概率  $D(O|T)$ 。

所提方法引入生成对抗网络的思想, 通过生成器和判别器间交替训练, 同时在训练过程中不断优化权重来实现判别器高效识别目标图像的目的, 训练示意图具体如图 3 所示。该过程具体是: 以桶探测器的值  $I_b(x, y)$  及对应的目标图像作为生成器的输入, 通过训练生成器输出高质量的重建鬼像  $O(x, y)$ , 并固定生




图 2 SDCGAN-GI 架构  
Fig. 2 SDCGAN-GI architecture

成器的参数不变, 将生成器输出的鬼像  $O(x, y)$  及目标图像为输入再对判别器进行训练, 重复上述过程直到网络收敛。该训练过程基于 SDCGAN 框架建立起了桶探测器的值与目标图像之间的完整映射。此重建过程可表示为

$$O(x, y) = R_{\text{SDCGAN}}\{I_{bm}\}, \forall m = 1, 2, \dots, M, \quad (3)$$

式中:  $R_{\text{SDCGAN}}\{\cdot\}$  表示 SDCGAN 将桶探测器的值映射回对象空间。为能够提高重建结果的质量, 所提方法所使用标记的数据集对都包含已知的目标图像  $T(x, y)^n$  和其对应的桶探测器的值  $I_{bm}^n$ , 其中  $n = 1, 2, \dots, N, N$  为训练的总标记对数。为此所用的网络结构可表示为

$$R_{\text{SDCGAN}} = \operatorname{argmin}_G \max_D L_{\text{SDCGAN}}(G, D) + \lambda L_{L_1}(G), \quad (4)$$

式中:  $\lambda L_{L_1}(G)$  是参数上的正则化项, 以避免训练过程中出现过拟合现象, 从而使生成器生成的图像更接近目标图像。

此外, 损失函数用于估计目标图像和重建结果之

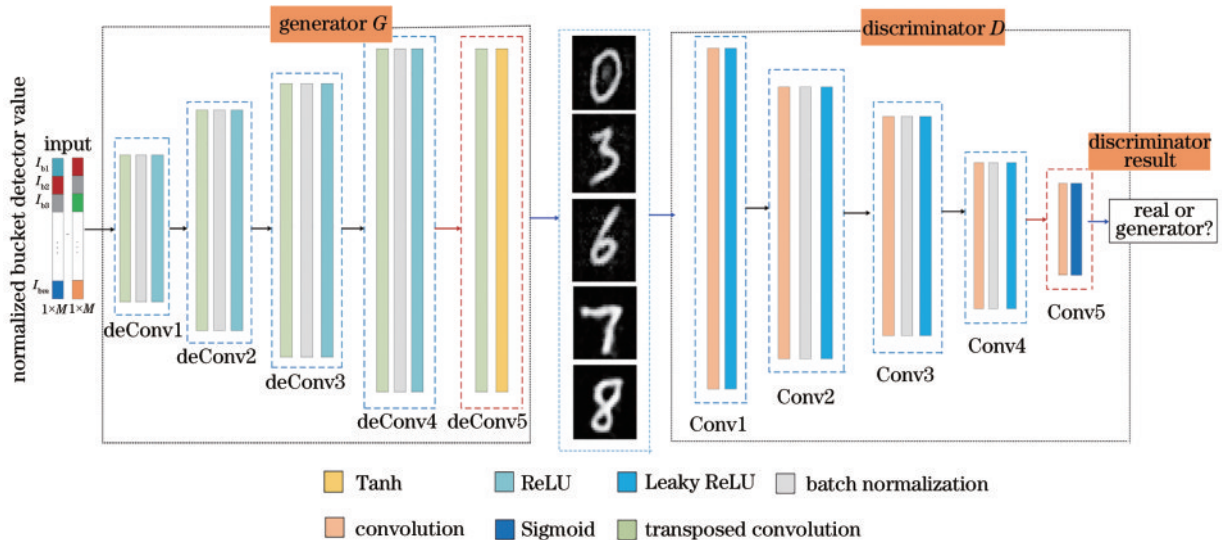


图 3 SDCGAN-GI 架构模型  
Fig. 3 SDCGAN-GI architecture model

间的差异。当损失函数减小时,二者越接近。所采用的对抗性损失函数可表示为

$$\min_G \max_D L_{SDCGAN}(G, D) = E[\log D(\mathbf{O}|\mathbf{T})] + E\{\log\{1 - D[G(\mathbf{B}|\mathbf{T})]\}\}. \quad (5)$$

### 2.3 网络架构设计

深度卷积生成对抗网络使用生成器和判别器的架构,通过有监督的学习方式并结合全卷积层,其局部连接的特殊结构所带来的稀疏连接、权值共享可有效解决网络过拟合的问题。

为此,所采用的基于深度卷积生成对抗网络的模型如图 3 所示。该生成模型由两部分组成:生成器和判别器。生成器的输入是长度为  $M$  的归一化的桶探测器的值,输出为生成的高质量的真像并将其作为判别器的输入,从而通过训练来判断输入的图像是来自目标图像还是来自生成的真像。判别器的输入为生成器训练生成的图像,通过训练判别器去判断输入的图像是来自目标图像还是来自生成的真像。

生成器和判别器分别由转置卷积块和卷积块组成,具体如下。

生成器由 5 个转置卷积块组成,每个转置卷积块由转置卷积层、批量归一化(BN)层和激活函数层组成。其中,隐藏层均选用修正线性单元(ReLU)为激活层,为使得训练更加稳定,生成器的输出层的激活函数为 Tanh。判别器选用的卷积块个数与生成器的转置卷积块个数相同,且每个卷积块由卷积层、批量归一化层和激活函数层组成。并选用 Leaky ReLU 作为判别器的激活函数,由于该激活函数的导数总是不为 0 可减少静默神经元的出现,不仅可以解决 ReLU 函数进入负区间后神经元不学习的问题,而且有利于改善梯度的稀疏性从而加快网络的拟合速度。

同时,BN 层能优化对权重的调整从而加快网络的训练和收敛速度,控制梯度爆炸防止梯度消失。为此,除生成器的输出层及判别器的输入层以外,生成器  $G$  和判别器  $D$  的其余转置卷积块和卷积块都添加了 BN 层,通过将特征层的输出归一化到一起,加速了网络的训练,提高了 SDCGAN 模型训练的稳定性。

此外,卷积在提取图像特征上具备很好的效果,本文均使用卷积层代替原始生成对抗网络的全连接层,且在训练过程中,通常需要通过上采样(up-sampling)来提高图像分辨率。因此,为了使网络学习出一种最优的上采样方法,该深度卷积生成对抗网络在生成器部分采用了转置卷积。

通过多次实验验证,所设计网络的架构参数如下:生成器的输入层的转置卷积核尺寸为  $4 \times 4$ ,步长为 1;生成器的隐藏层的转置卷积核尺寸为  $4 \times 4$ ,步长为 2;生成器输出层的转置卷积核尺寸为  $3 \times 3$ ,步长为 1;判别器的输入层的卷积核尺寸为  $4 \times 4$ ,步长为 1;判别器

的隐藏层的卷积核尺寸为  $4 \times 4$ ,步长为 2;判别器输出层的卷积核尺寸为  $2 \times 2$ ,步长为 1。对于上述所使用的网络层,均需要在卷积后对图像边缘进行零填充,通过这种方式,图像的输出与输入分辨率相同。

本文设计的框架使用的操作系统为 Win10 (64 位),编程语言 Python 版本 3.8 (64 位),基于 PyTorch 框架实现了深度卷积生成对抗网络模型,具体如图 3 所示。

## 3 分析与讨论

### 3.1 数据预处理

本文的数据集是公开的 MNIST 数据集的手写字体图片,经过数据扩充至  $28 \times 28$  到  $32 \times 32$ 。且 MNIST 是一个公开的手写数字的图片数据集,内容范围为 0~9 十类手写数字,由 60000 个训练样本和 10000 个测试样本组成。每个样本都是一张  $28 \times 28$  像素的灰度手写数字图片。

输入数据的分布也会影响模型的收敛速度和性能。因此在输入数据之前需要对训练数据进行预处理。对桶探测器的值进行归一化处理,采用最小最大规范的方法(min-max normalization),可表示为

$$I_{b(\text{normalization})} = \frac{I_b - V_{\min}}{V_{\max} - V_{\min}}, \quad (6)$$

使其映射到 0~1 范围,从而加快网络的收敛性。

### 3.2 评价指标的选取

为了客观准确地说明所提方法的有效性和合理性,引入峰值信噪比(PSNR)和结构相似性(SSIM)两个评价指标对重构的真像进行定量分析,并对不同采样率下的重构后的真像进行分析说明,即

$$R_{\text{PSNR}} = 10 \log_{10} \frac{V_{\text{MAXG}}^2}{E_{\text{MSE}}}, \quad (7)$$

$$V_{\text{SSIM}} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (8)$$

式中:  $E_{\text{MSE}} = \frac{1}{x \times y} \sum_{i=1}^x \sum_{j=1}^y [T(x, y) - T(x, y)]^2$

表示重构图像与原始图像的均方误差;  $x$  和  $y$  为物体像素数,是正整数;  $V_{\text{MAXG}}$  表示图像的最大灰度值;  $\mu_x$ 、 $\mu_y$ 、 $\sigma_x^2$ 、 $\sigma_y^2$ 、 $\sigma_{xy}$  分别表示重建图像和物体信息的均值、方差、协方差;  $c_1$  和  $c_2$  是为了防止分母为 0 而用来维持稳定的常数。

### 3.3 实验验证与结果分析

#### 3.3.1 SDCGAN 在不同采样率下的结果分析

利用 SDCGAN 分别在 0.39%、1.56%、6.25%、25%、100% 的采样率下进行实验,将每个采样率下的训练集的迭代次数均设置为 200 epoch,训练完成后利用测试集进行性能估计。0.39% 采样率即采样次数仅为 4 次 ( $0.39\% \times 1024 = 4$  次),由于所包含的一维桶探测器的值过少,给网络学习的信息过少,重构出的手

写数字图像噪声过大。在测试集中从 0~9 十类手写数字中随机挑选一张,以便展示所提方法在不同采样

率下的基于鬼成像思想重建的手写数字图像,如图 4 所示。




图 4 不同采样率下重构的手写数字图像

Fig. 4 Handwritten digital images reconstructed at different sampling rates

从最直观的视觉角度来看,在低至 1.56% 的采样率下所提方法仍能够得到与真实手写数字图像接近的结果图,如图 4 所示,说明搭建的网络架构能学习到图像的整体特征。大体上来说,都可以通过直接观察来获知重构图像的具体数字信息,在四种采样率下重构的数字“0”、“1”、“4”、“7”图像的质量都很高,重构图像的边缘纹理能够清晰显示,这与此类数字的笔画组成相对简单有着很大的关系。数字“2”、“3”、“6”、“8”、“9”均由较为复杂的曲线组成,在 6.25% 采样率的情况下能够恢复出较为清晰的数字“2”下部分的曲线且还原出了数字结构的顺滑性,在拐弯处不生硬,说明搭建的网络架构不仅能重构出手写数字的轮廓,对于结构的细节信息也能较为完整地重构出来。在 25% 的采样率下,除了数字“2”结构内仅有少量的星点噪声,其余重构数字的内部细节与边缘纹理的细节得到很好的重构。从图 4 的实验结果发现随着采样率的不断提升,数字的边缘纹理也在不断完善。

相应地,0.0625 的采样率代表  $(32 \times 32 \times 0.0625)$  64 次探测,低采样率范围为  $0 \leq \beta \leq 0.3$ 。实验中,为验证少量采样次数成像的可行性,在低采样率  $\beta=0.0625$ 、 $\beta=0.0156$  的情况下分别通过 GI、CSGI、Hadamard-GI、SDCGAN-GI 算法重构图像,实验结果分别如图 5 和图 6 所示。这里,0.0625 和 0.0156 采样率为  $32 \times 32 \times 0.0625$  和  $32 \times 32 \times 0.0156$ ,即 64 次和 16 次采样。其中图 5(a)和图 6(a)表示目标手写数字图像,图 5(b)和图 6(b)、图 5(c)和图 6(c)分别表示 0.0625 和 0.0156 采样率下 GI、CSGI 算法的重构结果,图 5(d)和图 6(d)分别表示 0.0625 和 0.0156 采样率下 Hadamard-GI 算法的重构结果,图 5(e)和图 6(e)分别为桶探测器的值作为网络输入的 SDCGAN-GI 在不同采样率下的重构结果。

在本文中,全采样率定义为 1024  $(32 \times 32)$  次探

图 5 和图 6 的实验结果表明:在  $\beta=0.0625$ 、 $\beta=0.0156$  时,GI、CSGI、Hadamard 传统鬼成像方法会造成完全失真,这是由于该类方法都需要大量的测量数据才能够重构图像,因此在采样率很低的情况下,易出




图 5 0.0625 采样率下不同算法的结果对比

Fig. 5 Comparison of the results of different algorithms at a sampling rate of 0.0625




图 6 0.0156 采样率下不同算法的结果对比

Fig. 6 Comparison of the results of different algorithms at a sampling rate of 0.0156

现区域模糊、重建效果差、失真的现象;但 SDCGAN-GI 可在低采样率的情况下重构出较清晰的目标图像且输出图像的边缘信息显著增强,背景散斑也能得到有效滤除,也为少量探测次数的成像提供了可能。并且在同一采样率下,GI 和 CSGI 始终包含明显噪声,尤其在较低的采样率下目标信息基本被掩盖;Hadamard-GI 成像效果完全失真;而经过模型训练后,SDCGAN-GI 的重构结果明显最优。

为进一步客观评价所提方法的优越性,利用 PSNR 来衡量对比 GI、CSGI、Hadamard-GI、SDCGAN-GI 4 种成像方法的图像质量。通常,PSNR 越大,图像重构效果越好。为此,绘制了在不同采样次数情况下 4 种成像方法所对应的 PSNR 曲线,如图 7 所示。实验数据表明:SDCGAN-GI 的 PSNR 值明显高于其他方法,并且能够在低采样率下还原出更优质图像。

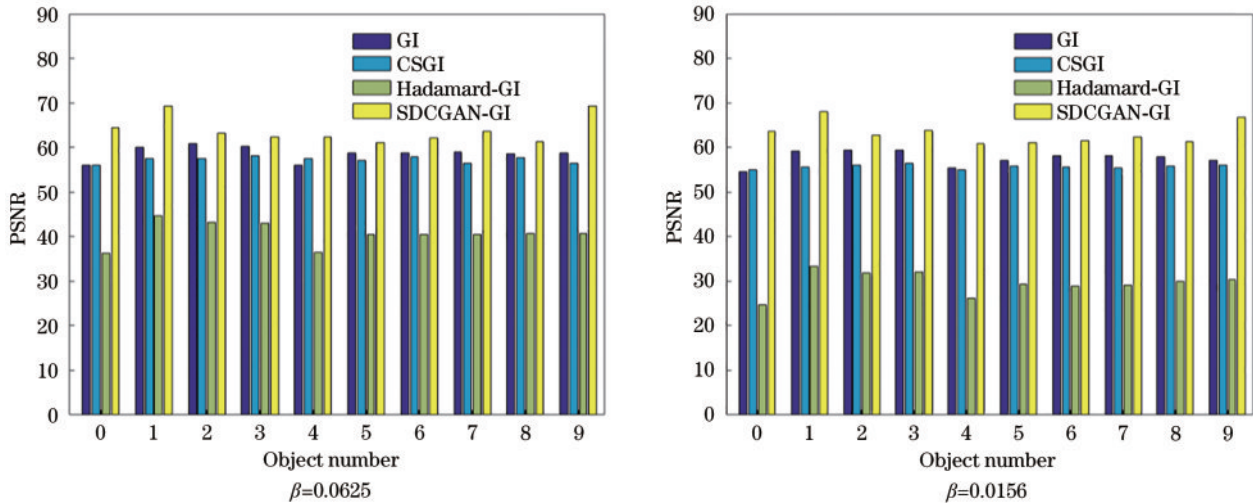


图 7 不同采样率下的峰值信噪比

Fig. 7 PSNR at different sampling rates

### 3.3.2 与 u-net 实验结果对比分析

为了进一步验证所提方法的有效性,比较了采样率  $\beta=0.25$ 、 $\beta=0.0625$  情况下 SDCGAN-GI 和 u-net-GI 的重构结果,结果如图 8 和图 9 所示。实验结果表明:SDCGAN-GI 重构的手写数字“9”较 u-net-GI 重构的更清晰。观察所提方法重构的图像可知,高清晰度使得输出图像的边缘信息更明显,且在采样率  $\beta=0.25$  时的 PSNR 和 SSIM 均高于 u-net-GI。

图 10 为不同采样率下 SDCGAN-GI 与 u-net-GI 的平均峰值信噪比和平均结构相似性。对 SDCGAN

与 u-net 进行对比分析,为了便于分析实验结果,在测试集中随机选取 100 张手写数字图像,利用式(7)和式(8)计算了平均峰值信噪比和平均结构相似性,得到了不同采样率下的数值,并绘制如图 10 所示的曲线图。

由图 10 可知:在全采样的情况下,u-net-GI 的平均峰值信噪比和平均结构相似性分别为 38.0591 和 0.9784;SDCGAN-GI 的平均峰值信噪比和平均结构相似性分别为 38.4965 和 0.9800。在采样率为 0.39%、1.56%、6.25%、25% 情况下,SDCGAN-GI、




图 8 SDCGAN 和 u-net 在采样率为 0.25 时的重构结果对比

Fig. 8 Comparison of reconstruction results of SDCGAN and u-net at a sampling rate of 0.25

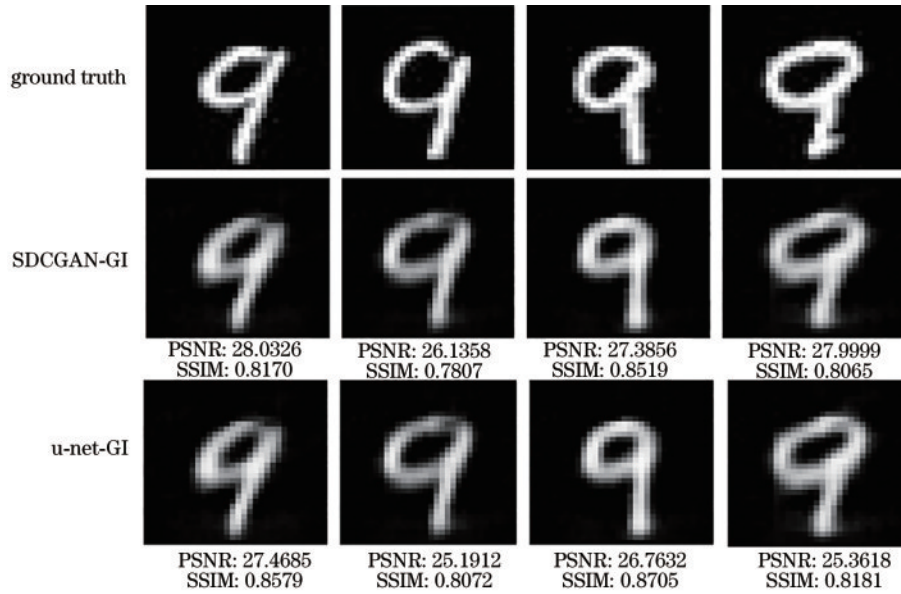


图 9 SDCGAN 和 u-net 在采样率为 0.0625 时的重构结果对比

Fig. 9 Comparison of reconstruction results of SDCGAN and u-net at a sampling rate of 0.0625




图 10 不同采样率下 SDCGAN 与 u-net 的平均峰值信噪比和平均结构相似性

Fig. 10 Average peak signal-to-noise ratio and average structural similarity between SDCGAN and u-net at different sampling rates

u-net-GI 的平均峰值信噪比和平均结构相似性具体如表 1 和表 2 所示。该结果与上述定性分析结果相一致。

表 1 不同采样率下 SDCGAN-GI 和 u-net-GI 的平均峰值信噪比较

Table 1 Comparison of average peak signal-to-noise ratio between SDCGAN-GI and u-net-GI at different sampling rates

Sampling rate /%	SDCGAN-GI	u-net-GI
0.39	9.8157	9.4954
1.56	11.6554	10.2425
6.25	12.5023	10.5131
25	18.0551	13.0557

表 2 不同采样率下 SDCGAN-GI 和 u-net-GI 的平均结构相似性比较

Table 2 Comparison of average structural similarity between SDCGAN-GI and u-net-GI at different sampling rates

Sampling rate /%	SDCGAN-GI	u-net-GI
0.39	0.1187	0.0779
1.56	0.4082	0.2587
6.25	0.4554	0.2998
25	0.7630	0.5360

## 4 结 论

结合深度学习可自动挖掘图像内部特征的优势,利用生成对抗网络提出了一种新的手写数字图像重构方法。相比传统重构方法,所提方法仅需要输入一维的桶探测器数值便可直接获得高质量的二维手写数字图像,且采样率在 0.0156 时仍能得到相对清晰的重构结果,明显优于传统 GI、CSGI 和 Hadamard-GI 方法。此外,通过与 u-net 网络的对比分析,说明所提方法在提升鬼成像重构质量方面更具优势性能,将其应用到现代人工智能技术中将有突破制约鬼成像工程化的瓶颈。在后续研究中,将结合文献[18]提出的 Hadamard 矩阵优化排序法对散斑图案进行排序后再进行后续操作,同时将进一步优化 SDCGAN 结构,以保证模型具有更好的泛化能力。

## 参 考 文 献

- [1] 王登峰,姚鑫,焦仲科,等.面向长距离量子通信的双光子关联成像技术[J].半导体光电,2020,41(4):542-547.  
Wang D F, Yao X, Jiao Z K, et al. Two-photon correlation imaging technique towards long-distance quantum communications[J]. Semiconductor Optoelectronics, 2020, 41(4): 542-547.
- [2] 石峰,陆同希,杨书宁,等.噪声环境下基于单像素成像系统和深度学习的目标识别方法[J].红外与激光工程,2020,49(6):20200010.  
Shi F, Lu T X, Yang S N, et al. Target recognition method based on single-pixel imaging system and deep learning in the noisy environment[J]. Infrared and Laser Engineering, 2020, 49(6): 20200010.
- [3] Ferri F, Magatti D, Lugiato L A, et al. Differential ghost imaging[J]. Physical Review Letters, 2010, 104(25): 253603.
- [4] Katz O, Bromberg Y, Silberberg Y. Compressive ghost imaging[J]. Applied Physics Letters, 2009, 95(13): 131110.
- [5] 张红伟,郭树旭,张驰,等.关联成像目标重构的伪逆迭代降噪方法[J].光子学报,2017,46(2):210001.  
Zhang H W, Guo S X, Zhang C, et al. Pseudo-inverse iterative denoising method for object reconstruction of ghost imaging[J]. Acta Photonica Sinica, 2017, 46(2): 210001.
- [6] 侯明轩,侯昌伦.关联成像应用及其最新进展[J].激光与光电子学进展,2023,60(2):0200003.  
Hou M X, Hou C L. Application of correlation imaging and its latest progress[J]. Laser & Optoelectronics Progress, 2023, 60(2): 0200003.
- [7] 孙鸣捷,闫崧明,王思源.鬼成像和单像素成像技术中的重建算法[J].激光与光电子学进展,2022,59(2):0200001.  
Sun M J, Yan S M, Wang S Y. Reconstruction algorithms for ghost imaging and single-pixel imaging[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0200001.
- [8] 宗岩峰,郑淮斌,吴鑫伟,等.基于时序控制的赝热光鬼成像系统[J].光学学报,2023,43(7):0711001.  
Zong Y F, Zheng H B, Wu X W, et al. Sequence-controlled pseudothermal optical ghost imaging system [J]. Acta Optica Sinica, 2023, 43(7): 0711001.
- [9] 张棋飞,孙瑞,丁毅,等.基于离散 W 变换的计算鬼成像方法[J].激光与光电子学进展,2023,60(22):2211003.  
Zhang Q F, Sun R, Ding Y, et al. Computational ghost imaging method based on discrete w transform[J]. Laser & Optoelectronics Progress, 2023, 60(22): 2211003.
- [10] 张思卿,杨风暴,王肖霞.基于自编码神经网络的鬼成像优化方法[J].电子测量技术,2021,44(21):77-83.  
Zhang S Q, Yang F B, Wang X X. Ghost imaging optimization method based on autoencoder neural network [J]. Electronic Measurement Technology, 2021, 44(21): 77-83.
- [11] 冯维,赵晓冬,吴贵铭,等.基于卷积神经网络的计算鬼成像方法研究[J].光子学报,2020,49(6):0610002.  
Feng W, Zhao X D, Wu G M, et al. Computational ghost imaging method based on convolutional neural network[J]. Acta Photonica Sinica, 2020, 49(6): 0610002.
- [12] Wei F, Sun X Y, Li X H, et al. High-speed computational ghost imaging based on an auto-encoder network under low sampling rate[J]. Applied Optics, 2021, 60(16): 4591-4598.
- [13] Wang F, Wang H, Wang H C, et al. Learning from simulation: an end-to-end deep-learning approach for computational ghost imaging[J]. Optics Express, 2019, 27(18): 25560-25572.
- [14] Yang X, Yu Z Y, Xu L, et al. Underwater ghost imaging based on generative adversarial networks with



- high imaging quality[J]. *Optics Express*, 2021, 29(18): 28388-28405.
- [15] Zhao M, Zhang X D, Zhang R F. Single-arm ghost imaging via conditional generative adversarial network[J]. *Laser Physics Letters*, 2021, 18(7): 075203.
- [16] Liu S P, Meng X F, Yin Y K, et al. Computational ghost imaging based on an untrained neural network[J]. *Optics and Lasers in Engineering*, 2021, 147: 106744.
- [17] Liu H, Chen Y N, Zhang L, et al. Color ghost imaging through the scattering media based on A-cGAN[J]. *Optics Letters*, 2022, 47(3): 569-572.
- [18] 李明飞, 阎璐, 杨然, 等. 基于Hadamard矩阵优化排序的快速单像素成像[J]. *物理学报*, 2019, 68(6): 064202.  
Li M F, Yan L, Yang R, et al. Fast single-pixel imaging based on optimized reordering Hadamard basis[J]. *Acta Physica Sinica*, 2019, 68(6): 064202.
- [19] 闫国庆, 杨风暴, 王肖霞, 等. 基于正交化正弦散斑的计  
算鬼成像[J]. *激光与光电子学进展*, 2020, 57(4): 041019.  
Yan G Q, Yang F B, Wang X X, et al. Computational ghost imaging based on orthogonal sinusoidal speckle[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041019.
- [20] Yan R N, He Q M, Liu Y Q, et al. Unpaired virtual histological staining using prior-guided generative adversarial networks[J]. *Computerized Medical Imaging and Graphics*, 2023, 105: 102185.
- [21] Zhang Y L, Liu Y C, Wang Y, et al. An ensemble oversampling method for imbalanced classification with prior knowledge via generative adversarial network[J]. *Chemometrics and Intelligent Laboratory Systems*, 2023, 235: 104775.
- [22] Liu X W, Wang R H, Huo H T, et al. An attention-guided and wavelet-constrained generative adversarial network for infrared and visible image fusion[J]. *Infrared Physics & Technology*, 2023, 129: 104570.